



centro adscrito a:



UNIVERSITAT POLITÈCNICA
DE CATALUNYA
BARCELONATECH

GUIA DOCENT DE

Anàlisi de Dades

Temporals

2026-27

DADES GENERALS

Número:	Anàlisi de Dades Temporals
Codi:	801362 (BUSINESSTECH)
Curs:	2026-27
Titulació:	Grau en Empresa, Innovació i Tecnologia
Nº de crèdits (ECTS):	6
Ubicació en el pla d'estudis:	3r. Curs, 2n. quadrimestre
Departament:	Mètodes Quantitatius
Responsable departament:	Dr. Iván Romero
Data de l'última revisió:	Juliol 2026
Professor Responsable:	Dr. Iván Romero

1. DESCRIPCIÓ GENERAL

L'assignatura Anàlisi de Dades Temporals s'emmarca en el tercer curs de la menció d'Analítica de Negoci del Grau en Empresa, Innovació i Tecnologia. El seu propòsit és capacitar l'estudiant per comprendre, modelitzar i predir fenòmens econòmics i empresarials que evolucionen al llarg del temps, mitjançant l'ús de tècniques estadístiques i computacionals avançades.

L'anàlisi de sèries temporals constitueix una disciplina fonamental en l'àmbit de l'analítica de negoci, atès que la majoria de les dades empresarials —vendes, demanda, preus, indicadors financers o mètriques operatives— es registren i analitzen en funció del temps. Aquesta assignatura proporciona a l'estudiant les eines necessàries per extreure patrons, identificar tendències, modelitzar comportaments i generar prediccions que donin suport a la presa de decisions informades en contextos empresarials reals.

L'assignatura s'estructura en cinc blocs temàtics. En el primer bloc s'estableixen els conceptes fonamentals de les sèries temporals: la seva definició, tipologia, components i les tècniques inicials d'exploració i visualització amb Python. El segon bloc aborda l'estadística aplicada a sèries temporals, amb especial atenció a l'estacionarietat, l'autocorrelació i les eines de diagnòstic. En el tercer bloc s'estudien els models clàssics de predicció, incloent estratègies de validació, descomposició, mitges mòbils i suavitzat exponencial. El quart bloc introdueix els models ARIMA i les seves variants estacionals i amb variables exògenes, així com el model Prophet. El cinquè i últim bloc incorpora l'enfocament del machine learning aplicat a la predicció de sèries temporals, cobrint algorismes d'ensemble i xarxes neuronals recurrents.

Al llarg de l'assignatura, l'estudiant treballarà amb eines de programació —principalment Python— per al processament, modelització i visualització de dades temporals, consolidant així competències tècniques directament transferibles a l'entorn professional.

2. OBJECTIUS

En finalitzar el curs l'estudiant serà capaç de:

- Comprendre la naturalesa específica de les dades temporals i diferenciar-les d'altres tipus de dades estadístiques.
- Identificar i descriure les principals components d'una sèrie temporal: tendència, estacionalitat, cicle i residu.
- Aplicar tècniques estadístiques per a l'anàlisi de l'estacionarietat i l'autocorrelació de sèries temporals.
- Implementar models clàssics de predicció com la descomposició, el suavitzat exponencial i les mitjanes mòbils.
- Construir i validar models ARIMA, SARIMA i altres variants per a la predicció de sèries temporals.
- Aplicar algorismes de machine learning a problemes de predicció temporal, avaluant el seu rendiment amb mètriques adequades.
- Utilitzar Python com a eina principal per a la implementació, visualització i avaluació de models de sèries temporals.
- Interpretar els resultats dels models en contextos empresarials reals i comunicar les prediccions de manera efectiva.
- Avaluar críticament la idoneïtat de cada model en funció de les característiques de les dades i els objectius de l'anàlisi.

3. RESULTATS DE L'APRENENTATGE

- Identificar i caracteritzar una sèrie temporal, reconeixent els seus components i comprenent les seves implicacions analítiques en un context empresarial.
- Aplicar proves estadístiques d'estacionarietat i analitzar les funcions d'autocorrelació (ACF) i autocorrelació parcial (PACF) per diagnosticar el comportament d'una sèrie temporal.

- Seleccionar, estimar i validar models clàssics de predicció (mitjanes mòbils, suavitzat exponencial, descomposició) justificant l'elecció en funció de les propietats de les dades.
- Identificar l'ordre d'un model ARIMA/SARIMA a partir de l'anàlisi dels correlogrames, estimar els seus paràmetres i interpretar els resultats obtinguts.
- Implementar i comparar models de predicció basats en machine learning, aplicant tècniques de validació creuada temporal i mètriques d'avaluació com MAE, RMSE i MAPE.
- Comunicar de forma clara i estructurada els resultats de l'anàlisi de sèries temporals, adaptant el discurs tècnic a perfils no especialitzats.

4. CONTINGUTS

TEMA 1. EL SISTEMA GENERADOR EN SÈRIES TEMPORALS

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Comprendre el concepte de sistema generador com a mecanisme subjacent — determinista, estocàstic o mixt— que produeix els valors observats d'una sèrie temporal.
- Diferenciar entre sistemes deterministes, estocàstics i mixtos, identificant exemples representatius en contextos empresarials.
- Comprendre el problema d'identificació del sistema generador: per què diferents sistemes poden produir sèries estadísticament indistingibles.
- Interpretar de forma conceptual els invariants que caracteritzen un sistema generador (memòria, horitzó de predictibilitat, complexitat), sense necessitat de la seva formalització matemàtica avançada.
- Relacionar cada bloc temàtic posterior de l'assignatura amb l'aspecte del sistema generador que pretén capturar.

Contingut

- 1.1. El sistema generador com a mecanisme subjacent a la sèrie observada.
- 1.2. Taxonomia de sistemes generadors: deterministes, estocàstics i mixtos.
- 1.3. El problema d'identificació: la sèrie com a projecció observable del sistema.
- 1.4. Memòria del sistema i persistència: nocions introductòries (exponent de Hurst).
- 1.5. Horitzó de predictibilitat: límits estructurals de qualsevol model.
- 1.6. Heterocedasticitat: quan l'impredictible és la volatilitat i no la mitjana.

1.7. El model com a aproximació al sistema generador: mapa conceptual de l'assignatura.

TEMA 2. CONCEPTES FONAMENTALS DE SÈRIES TEMPORALS

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Definir què és una sèrie temporal i distingir-la d'altres tipus de dades estadístiques.
- Identificar fonts i estratègies de recerca de dades de sèries temporals.
- Aplicar tècniques d'enginyeria de característiques temporals: lags, finestres lliscants i variables temporals.
- Realitzar una anàlisi exploratòria i de visualització de sèries temporals a Python.
- Identificar i descriure les components d'una sèrie temporal: tendència, estacionalitat, cicle i residu.

Contingut

- 2.1. Definició i tipus de sèries temporals.
- 2.2. Recerca de dades de sèries temporals.
- 2.3. Enginyeria de característiques per a sèries temporals: lags, finestres lliscants i variables temporals.
- 2.4. Anàlisi exploratòria i visualització de sèries temporals a Python.
- 2.5. Components d'una sèrie temporal: tendència, estacionalitat, cicle i residu.
- 2.6. Anàlisi exploratòria i visualització de sèries temporals a Python.

TEMA 3. ESTADÍSTICA APLICADA A SÈRIES TEMPORALS

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Comprendre i contrastar l'estacionarietat d'una sèrie temporal mitjançant proves estadístiques (ADF, KPSS).
- Calcular i interpretar les funcions d'autocorrelació (ACF) i autocorrelació parcial (PACF).
- Interpretar correlogrames com a eina de diagnòstic d'un model.
- Aplicar transformacions per a l'estabilització de la variància i la mitjana d'una sèrie temporal.

Contingut

- 3.1. Estacionarietat: concepte, tipus i proves estadístiques (ADF, KPSS).
- 3.2. Funció d'autocorrelació (ACF) i autocorrelació parcial (PACF).
- 3.3. Correlogrames: interpretació i ús diagnòstic.
- 3.4. Transformacions per a l'estabilització de la variància i la mitjana.

TEMA 4. MODELS CLÀSSICS DE PREDICCIÓ

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Aplicar estratègies de validació creuada temporal: walk-forward i blocked cross-validation.
- Avaluar la precisió de les prediccions mitjançant mètriques estàndard (MAE, RMSE, MAPE).
- Justificar les limitacions de la regressió lineal com a estratègia de predicció temporal.
- Aplicar el mètode de descomposició additiva i multiplicativa per separar les components d'una sèrie temporal.
- Implementar models de mitges mòbils simples i ponderades.
- Implementar models de suavitzat exponencial simple, doble (Holt) i triple (Holt-Winters).

Contingut

- 4.1. Estratègies de predicció: validació creuada temporal (walk-forward i blocked cross-validation).
- 4.2. Mètriques d'avaluació: MAE, RMSE, MAPE.
- 4.3. Limitacions de la regressió lineal en la predicció de sèries temporals.
- 4.4. Descomposició de sèries temporals: mètodes additiu i multiplicatiu.
- 4.5. Mitges mòbils simples i ponderades.
- 4.6. Suavitzat exponencial simple, doble (Holt) i triple (Holt-Winters).

TEMA 5. MODELS ARIMA I VARIANTS

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Comprendre els models AR, MA i ARMA, les seves propietats, avantatges i desavantatges enfront d'altres enfocaments.
- Aplicar el procés d'identificació, estimació i validació de models ARIMA.

- Estendre el model ARIMA a la seva variant estacional (SARIMA) per a sèries amb estacionalitat.
- Incorporar variables exògenes mitjançant models ARIMAX/SARIMAX.
- Aplicar criteris de selecció de models (AIC, BIC) i analitzar els residus del model.
- Implementar el model Prophet (Meta) per a predicció amb estacionalitats múltiples.

Contingut

- 5.1. Models AR, MA i ARMA: definició i propietats. Avantatges i desavantatges dels mètodes estadístics.
- 5.2. Procés d'identificació, estimació i validació de models ARIMA.
- 5.3. Models SARIMA per a sèries amb estacionalitat.
- 5.4. Models ARIMAX/SARIMAX amb variables exògenes.
- 5.5. Criteris de selecció: AIC, BIC i anàlisi de residus.
- 5.6. Prophet (Meta) per a predicció amb estacionalitats múltiples.

TEMA 6. PREDICCIÓ AMB MACHINE LEARNING

Resultats específics de l'aprenentatge

L'estudiant després d'estudiar el tema i realitzar els exercicis, serà capaç de:

- Implementar i comparar models d'ensemble: Random Forest i Gradient Boosting (XGBoost, LightGBM).
- Implementar xarxes neuronals recurrents (LSTM i GRU) per a la predicció de sèries temporals.
- Avaluar els avantatges i desavantatges del deep learning enfront de mètodes estadístics clàssics en sèries temporals.

Contingut

- 6.1. Models d'ensemble: Random Forest i Gradient Boosting (XGBoost, LightGBM).
- 6.2. Xarxes neuronals recurrents: LSTM i GRU.
- 6.3. Avantatges i desavantatges del deep learning per a sèries temporals.

5. METODOLOGIA D'ENSENYAMENT I APRENTATGE

L'assignatura Anàlisi de Dades Temporals, situada en el tercer curs de la menció d'Anàlisi de Negoci, capacita l'estudiant per comprendre, modelitzar i predir fenòmens econòmics i empresarials que evolucionen al llarg del temps. El seu enfocament parteix de la

comprensió profunda dels mecanismes que generen les dades temporals —el sistema generador com a marc conceptual de tota l'assignatura— i progressa cap a la implementació pràctica de models predictius a Python sobre dades empresarials reals. La modalitat semipresencial combina sessions presencials de treball intensiu amb sessions asíncrona que permeten consolidar l'aprenentatge autònom.

La modalitat s'articula en 6 sessions presencials en aula física, 6 sessions asíncrones (o síncrones quan així ho determini el professorat) i 1 sessió d'examen final presencial, sumant un total de 13 sessions.

Sessions presencials (6 sessions):

Cada sessió combina una part expositiva i una part pràctica d'un mínim d'hora i mitja. En la part teòrica, el professorat introdueix els conceptes, models i marcs interpretatius del bloc temàtic corresponent recolzant-se en el material docent i els notebooks del campus virtual. Les sessions parteixen del sistema generador com a mecanisme subjacent a qualsevol sèrie observada i progressen cap a la implementació de models clàssics, ARIMA i de machine learning. Es fomentarà la participació activa mitjançant la interpretació conjunta de correlogrames, la discussió crítica sobre els límits de cada model i l'anàlisi de casos empresarials reals. A la part pràctica, l'estudiant —de forma individual o en grup— implementarà models i analitzarà dades temporals a Python. Almenys 4 de les 6 sessions presencials inclouran obligatòriament aquesta part pràctica amb activitat avaluable. L'ordre d'ambdues parts podrà variar segons criteri pedagògic del professorat, i no s'avisarà amb antelació del moment exacte de l'activitat pràctica, per tal d'afavorir l'assistència completa a cada sessió.

Sessions asíncrones (6 sessions):

Les sessions asíncrones s'articularen mitjançant materials docents, notebooks de Python estructurats per tema i recursos publicats al campus virtual, preparats específicament per als continguts de l'assignatura. Almenys 4 d'aquestes 6 sessions inclouran una part pràctica d'un mínim d'hora i mitja que l'estudiant podrà desenvolupar de forma asíncrona, o de forma síncrona si així ho decideixi el professorat. Almenys 4 sessions asíncrona comptaran amb algun tipus d'activitat avaluable.

Les principals activitats que es realitzaran al llarg de les sessions presencials i asíncrona són:

- Estudi i preparació dels continguts a partir del material docent i notebooks del campus virtual.

- Classes expositives (presencials o asíncrona) sobre el sistema generador, sèries temporals, models estadístics i tècniques de machine learning aplicades a la predicció.
- Anàlisi exploratòria i visualització de sèries temporals a Python, incloent enginyeria de característiques (lags, finestres lliscants, variables temporals).
- Diagnòstic estadístic: proves d'estacionarietat (ADF, KPSS), càlcul i interpretació d'ACF/PACF i correlogrames.
- Implementació i comparació de models clàssics (descomposició, mitges mòbils, Holt-Winters) i models ARIMA/SARIMA/Prophet amb avaluació mitjançant MAE, RMSE i MAPE.
- Implementació de models de machine learning per a predicció temporal (Random Forest, XGBoost, LightGBM, LSTM/GRU) amb validació creuada temporal.
- Lliuraments pràctics per tema, amb elaboració autònoma prèvia i resolució o exposició obligatòria en sessió.

Es proporcionaran notebooks de Python estructurats per tema, disponibles al campus virtual, per consolidar l'aprenentatge autònom fora de les sessions. La progressió tècnica anirà des de la conceptualització del sistema generador i l'anàlisi exploratòria fins als models de deep learning aplicats a sèries temporals empresarials.

6. AVALUACIÓ

Les tasques i activitats avaluatives s'ajustaran al contingut del material docent exposat a classe i facilitat al Campus per comprovar que l'alumnat els ha consolidat. D'acord amb el Pla Bolonya, el model premia l'esforç constant i continuat de l'estudiantat. Un 40% de la nota s'obté de l'avaluació contínua i el 60% restant, de l'examen final presencial. L'examen final té dues convocatòries.

La nota final de l'assignatura (NF) es calcularà a partir de la següent fórmula:

- **NF = Nota Examen Final x 60% + Nota Avaluació Continuada x 40%**
- Nota mínima de l'examen final per calcular la NF serà de 40 punts sobre 100.
- L'assignatura queda aprovada amb una NF igual o superior a 50 punts sobre 100.

Tipus d'activitat	Descripció	% Avaluació contínua	
Lliuraments per tema:			30%
Ex. Tema 1	Lliurament per Classlife	16%	
Ex. Tema 2	Lliurament per Classlife	16%	
Ex. Tema 3	Lliurament per Classlife	16%	

Ex. Tema 4	Lliurament per Classlife	16%	
Ex. Tema 5	Lliurament per Classlife	16%	
Ex. Tema 6	Lliurament per Classlife	20%	
Activitats en sessió	Exercicis, anàlisi de casos, proves curtes o altres activitats realitzades durant la part pràctica de les sessions. Mínim 6 tindran avaluació numèrica.	(integrades en el 30%)	
Examen final			60%
	Examen final	100%	

7. BIBLIOGRAFIA

- Box, G.E.P., Jenkins, G.M., Reinsel, G.C. y Ljung, G.M. (2015). Time Series Analysis: Forecasting and Control. 5ª ed. Hoboken, Estados Unidos: Wiley.
- Brockwell, P.J. y Davis, R.A. (2016). Introduction to Time Series and Forecasting. 3ª ed. Nueva York, Estados Unidos: Springer.
- Nielsen, A. (2019). Practical Time Series Analysis. Sebastopol, Estados Unidos: O'Reilly.
- Peixeiro, M. (2022). Time Series Forecasting in Python. Shelter Island, Estados Unidos: Manning Publications.